

МЕТОДЫ И СРЕДСТВА ОБРАБОТКИ И ИНТЕРПРЕТАЦИИ
КОСМИЧЕСКОЙ ИНФОРМАЦИИ

СЕГМЕНТАЦИЯ СПУТНИКОВЫХ СНИМКОВ ОБЛАЧНОСТИ
ПО ТЕКСТУРНЫМ ПРИЗНАКАМ НА ОСНОВЕ
НЕЙРОСЕТЕВЫХ ТЕХНОЛОГИЙ

© 2011 г. В. Г. Астафуров^{1,2*}, А. В. Скороходов²

¹ Томский государственный университет систем управления и радиоэлектроники, Томск

² Учреждение Российской академии наук Институт оптики атмосферы им. В.Е. Зуева
Сибирского отделения РАН, Томск

*E-mail: astafurov@iao.ru

Поступила в редакцию 13.01.2011 г.

Предложен новый подход к формированию наборов информативных текстурных признаков, определяемых на основе матрицы смежности градаций яркости изображения. Метод основан на анализе степени изменчивости текстурных признаков и величине их коэффициентов корреляции. Приводятся наборы информативных признаков для спутникового изображения спектрорадиометра MODIS и нескольких размеров скользящего окна. Для сегментации спутниковых изображений используется алгоритм на основе самоорганизующейся нейронной сети Кохонена. Обсуждаются результаты сегментации.

Ключевые слова: типы облаков, сегментация, текстурные признаки, нейронная сеть

ВВЕДЕНИЕ

Результаты дистанционного зондирования Земли (ДЗЗ) из космоса используются для решения широкого круга задач, связанных с метеорологией, переносом загрязнений, сельским и лесным хозяйством. Для решения некоторых из перечисленных задач требуются данные о типах облачности, согласно принятым в метеорологии стандартам (Мазин, Хргиан, 1989), и подстилающей поверхности. В настоящее время существует множество систем космического базирования, предназначенных для ДЗЗ, которые позволяют получать информацию с различным пространственным и спектральным разрешением. Системы IKONOS, ALOS, QuickBird и др. характеризуются высоким пространственным разрешением до 10 м и небольшой шириной полосы обзора от 10 до 600 км. Изучение и контроль глобальных процессов в атмосфере и на земной поверхности связаны с использованием данных спектрорадиометров MODIS, MERIS, AVHRR и др. с низким пространственным разрешением (>100 м) и полосой обзора 1000–3000 км.

Решение проблемы сегментации спутниковых изображений связано, во-первых, с выбором алгоритма сегментации и, во-вторых, с формированием набора информативных признаков, с учетом особенностей исходных данных и решаемой задачи. Например, для облаков недостаточно их физических характеристик, таких как температура верхней границы, альbedo, значение индексов

NDVI и NDSI и ряд других, которые можно восстановить по спутниковым данным. При этом различные типы облачности и подстилающей поверхности отличаются по своей текстуре, под которой будем понимать некоторым образом организованный локальный участок изображения, обладающий свойством однородности видеоданных. Применение текстурных признаков позволяет описать различные типы облачности и подстилающей поверхности по структуре изображения или его текстуре как некоторой универсальной классификационной характеристики. В ряде случаев при решении задач классификации использование текстурных признаков является более предпочтительным, чем использование физических характеристик, полученных по данным ДЗЗ. Например, в работе (Захваткина и др., 2009) показано, что использование текстурных признаков и статистик высокого порядка вносит более весомый вклад в разделение льдов по типам, чем их удельная эффективная площадь рассеяния. Данные ДЗЗ позволяют сформировать облачную маску (Shiffman, 2004), не проводя классификацию облачности по типам, а текстурные признаки – описывать яркостную неоднородность, которая характерна для различных типов облачных образований (Потапов, 2003). Для измерения и описания текстуры можно использовать различные статистические подходы. Один из них основан на вычислении матрицы смежности (Харалик, 1979), которая характеризует пространственное распределение и пространственную вза-

Таблица 1. Описание текстуры различных типов облаков

Тип облаков	Описание текстуры
Перистые	Волокнистая структура нитевидной формы, волокна которой расположены параллельно друг другу.
Слоистые	Однородные матовые участки, которые имеют серый и светло-серый тон.
Кучевые	Характерная структура изображения зернистая или волокнистая (ячейки, полосы, цепочки). Имеет большую яркостную неоднородность. Ее тон изменяется от серого и черного до ярко-белого.
Слоисто-кучевые	Характерна зернистая структура, которая имеет вид крупных или мелких гранул. Иногда она представляет собой изолированные расплывшиеся пятна, в центре которых, как правило, прослеживается относительно яркое образование. Имеет серый и светло-серый тон на ИК изображениях, светлый и ярко-белый тон на снимках, полученных в видимом диапазоне спектра.
Кучево-дождевые	Характеризуется яркими белыми пятнами с более темными краями.

имосвязь значений яркости локальной области изображения. В указанном обзоре отмечается возможность использования таких текстур для описания спутниковых изображений, их сегментации и идентификации различных типов облачности.

В настоящее время не существует универсального подхода к формированию информативного набора текстурных признаков (ТП), обеспечивающих, например, минимум средних ошибок распознавания (ошибка отнесения распознаваемого объекта к определенному классу). Процедура формирования такого набора ТП зависит от выбранных характеристик текстуры и используемого алгоритма сегментации. При этом следует прежде всего определить функционал информативности подсистемы признаков. В работе (Мицель и др., 2005) предложен метод формирования набора ТП, вычисленных на основе матриц смежности и используемых для непараметрического алгоритма текстурного анализа, с оценкой их информативности по величине эмпирического риска, а в статье (Харалик, 1979) рассмотрен другой подход, основанный на вычислении собственных векторов.

В данной работе описывается методика сегментации спутниковых снимков с помощью алгоритма на основе самоорганизующейся нейронной сети Кохонена и текстурных признаков изображения.

ТЕКСТУРА ОБЛАКОВ

Различают три основных типа текстуры – матовая, зернистая и волокнистая (Герман, 1975):

1) матовая текстура характеризуется однородным тоном изображения. Спутниковые снимки этой текстуры отличаются между собой только по яркости. Она свойственна изображениям открытых участков водной поверхности, суши в районах достаточного увлажнения, засушливых участ-

ков суши, сплошных льдов и снежного покрова, тумана и слоистых облаков;

2) зернистая текстура – скопление пятен (зерен) светлого или темного цвета на соответствующем фоне. Мелкие зерна обычно характерны для изображений кучевых облаков. Размеры зерен в этом случае настолько малы, что детали и формы отдельных облаков полностью скрадываются. Слоисто-кучевые облака выглядят аналогично, только зерна в этом случае более темные на светлом фоне. При этом зерна соответствуют просветам между облаками;

3) волокнистая текстура представляется в виде нитей (волокон), которая схожа с текстурой среза стволов деревьев.

Рассмотренные характеристики могут лечь в основу классификации типов облаков и подстилающей поверхности на спутниковых снимках, сделанных в видимом диапазоне спектра. Необходимо отметить, что не всегда удается точно классифицировать различные типы облаков из-за их сходства на аэрокосмических снимках. Кроме этого, проявление текстуры облачности и подстилающей поверхности будет отличаться (по размеру, по детализации контура и т.д.) для систем ДЗЗ с различной разрешающей способностью. Поэтому следует использовать условную классификацию облаков и подстилающей поверхности по ТП, составленную с учетом спектральных характеристик и пространственного разрешения аппаратуры ДЗЗ.

В табл. 1, составленной по материалам (Герман, 1975; Мазин, Хргиан, 1989), приведены некоторые типы облаков и описание их текстур. Данные характеристики позволяют увидеть отличия в текстурах различных типов облаков и сопоставить их с реальными спутниковыми снимками. Подобные таблицы можно составить и для подстилающей поверхности, например, так, как это сделано в работе (Харалик, 1979) для песчаника.

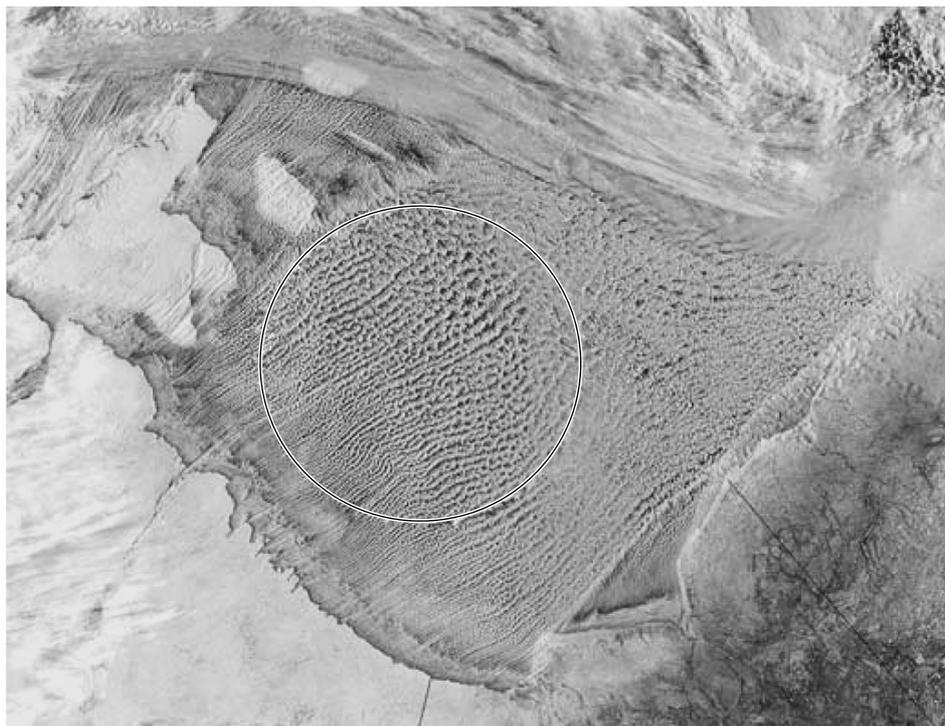


Рис. 1. Фрагмент снимка со спутника Terra (MODIS) над заливом Гудзона.

На рис. 1 выделенный участок облачного поля имеет большую яркостную неоднородность, тон меняется от белого до серого и черного, текстура имеет форму цепочек. Согласно данным табл. 1, этот участок соответствует кучевой облачности и его можно использовать в качестве эталона для данного типа облаков.

СИСТЕМА ТЕКСТУРНЫХ ПРИЗНАКОВ

Для сегментации используется система текстурных признаков, рассчитанных на основе матрицы пространственной зависимости градаций яркости P , называемой также матрицей смежности (Потапов, 2003; Харалик, 1979). Элементы матрицы $P_{i,j}$ рассчитываются по фрагменту изображения, выделенному скользящим окном с размерами n_x, n_y по вертикали и горизонтали соответственно. Подробное описание методики вычисления элементов матрицы смежности приведено в статье (Харалик, 1979). Нами использовалась приведенная ниже система ТП, формулы для вычисления которых и их интерпретация взяты из работы (Мицель и др., 2005).

Энергия

$$T_1 = \sum_{i=0}^{K-1} \sum_{j=0}^{K-1} P_{i,j}^2, \quad (1)$$

где K – число градаций яркости изображения.

Энтропия

$$T_2 = - \sum_{i=0}^{K-1} \sum_{j=0}^{K-1} P_{i,j} \lg P_{i,j} \quad (2)$$

характеризует неравномерность распределения яркостных свойств элементов изображения.

Максимальная вероятность

$$T_3 = \max_{i,j} P_{i,j}. \quad (3)$$

Первый начальный момент, или среднее значение яркости изображения в скользящем окне

$$T_4 = s^{-2} \sum_{i=1}^{n_x} \sum_{j=1}^{n_y} I_{i,j}, \quad (4)$$

где $s = n_x \times n_y$, $I_{i,j}$ – оцифрованный уровень яркости элемента (i, j) изображения, выделенного скользящим окном.

Вариация

$$T_5 = \sum_{g=0}^{K-1} (g - T_4)^2 F(g), \quad (5)$$

где $F(g)$ – количество пикселей с яркостью g в скользящем окне.

Однородность

$$T_6 = \sum_{i=0}^{K-1} \sum_{j=0}^{K-1} P_{i,j} / (1 + |i - j|). \quad (6)$$

Второй угловой момент

$$T_7 = \sum_{i=0}^{K-1} \sum_{j=0}^{K-1} (P_{i,j} / M)^2, \quad (7)$$

где M – общее количество пар примыкающих к друг к другу элементов. Второй угловой момент является мерой гомогенности изображения.

Контраст

$$T_8 = \sum_{n=0}^{K-1} n^2 \sum_{i=1}^K \sum_{j=1}^K P_{i,j} / M, \quad |i - j| = n \quad (8)$$

определяется величиной локальных вариаций яркости изображения. С ростом числа локальных вариаций яркостей контраст возрастает.

Дисперсия

$$T_9 = \sum_{i=1}^K \sum_{j=1}^K (i - m)^2 (P_{i,j} / M), \quad (9)$$

где

$$m = \frac{1}{K^2} \sum_{i=1}^K \sum_{j=1}^K P_{i,j}$$

– среднее значение элементов матрицы смежности. Дисперсия определяет вариации яркости относительно среднего значения.

Момент обратной разности, или инверсия

$$T_{10} = \sum_{i=1}^K \sum_{j=1}^K [1 + (i - j)^2] (P_{i,j}^2 / M) \quad (10)$$

тесно связана с контрастом и отражает степень разброса значений элементов матрицы смежности относительно ее главной диагонали. Этот признак является альтернативой контрасту в случае влияния краевых структур, поскольку относительно большие разности в значениях яркости вносят минимальный вклад в конечный результат.

Суммарное среднее

$$T_{11} = \sum_{n=1}^{2K} n p_+(n), \quad (11)$$

где $p_+(n) = \sum_{i=1}^K \sum_{j=1}^K P_{i,j} / M$ при $i + j = n, n = 2, 3, \dots, 2K$ – гистограмма сумм значений яркости.

Суммарная энтропия

$$T_{12} = \sum_{n=1}^{2K} p_+(n) \lg(p_+(n)) \quad (12)$$

характеризует неравномерность распределения яркостных свойств элементов изображения.

Информативным считается такой ТП, который неоднороден на заданном фрагменте изображения и некоррелирован с другими ТП. Степень изменчивости или неоднородности ТП δ_i определяется величиной его относительного среднеквадратического отклонения

$$\delta_i = \frac{\sigma_i}{m_1[T_i]}, \quad (13)$$

где σ_i – среднеквадратическое отклонение ТП T_i для выбранного фрагмента изображения, $m_1[T_i]$ – его среднее значение. Чем больше величина δ_i , тем более информативен данный ТП. И, наоборот, уменьшение величины δ_i показывает, что различные участки фрагмента изображения незначительно отличаются по данному признаку и его использование для сегментации или классификации не приведет к разделению различных текстур. Коэффициент корреляции $r_{i,j}$ характеризует степень зависимости значений пары ТП T_i, T_j на данном фрагменте.

Нами предложена следующая методика для формирования набора информативных текстурных признаков:

1. Выбирается фрагмент исследуемого изображения.
2. Фрагмент обрабатывается с помощью скользящего окна заданного размера и вычисляется набор значений текстурных признаков $T_i, i = \overline{1, 12}$.
3. Для каждого ТП вычисляются степень изменчивости δ_i и оценки коэффициентов корреляции $\hat{r}_{i,j}$ различных пар T_i, T_j ТП на заданном фрагменте изображения по формуле

$$\hat{r}_{i,j} = \frac{\sum_{k=1}^N ((x_{i,k} - \hat{m}_1[T_i]))((x_{j,k} - \hat{m}_1[T_j]))}{\left\{ \sum_{k=1}^N (x_{i,k} - \hat{m}_1[T_i])^2 \sum_{k=1}^N (x_{j,k} - \hat{m}_1[T_j])^2 \right\}^{1/2}}. \quad (14)$$

Здесь $\{x_{i,k}\}, k = \overline{1, N}$ – набор значений i -го ТП для выбранного фрагмента; N – число рассчитанных значений ТП для данного фрагмента;

$$\hat{m}_1[T_i] = \frac{1}{N} \sum_{k=1}^N x_{i,k}$$

– выборочное среднее значение i -го ТП.

Таблица 2. Значения порога r^* для различных размеров скользящего окна

$n_x \times n_y$	N	r^*		
		$\alpha = 0.005$	$\alpha = 0.01$	$\alpha = 0.1$
4×4	2500	0.06	0.05	0.03
8×8	625	0.11	0.10	0.06
16×16	169	0.19	0.18	0.12
20×20	100	0.24	0.22	0.15
40×40	25	0.13	0.14	0.16

4. Формируется набор информативных текстурных признаков.

Для оценки значимости коэффициента корреляции выбранной пары текстурных признаков используется методика, описанная в (Бендат, Пирсол, 1989), согласно которой проверяется гипотеза $H_0 : r_{i,j} = 0$ о равенстве нулю коэффициента корреляции i -го и j -го ТП при конкурирующей гипотезе $H_1 : r_{i,j} \neq 0$, т.е. корреляция является значимой. Если нулевая гипотеза отвергается, то это означает, что коэффициент корреляции значимо отличается от нуля, а ТП можно считать коррелированными. В этом случае следует считать, что их совместное использование нецелесообразно. Если принимается нулевая гипотеза, то корреляцией соответствующих ТП можно пренебречь, и оба признака будем считать информативными.

В качестве статистики критерия использовалась случайная величина

$$w_{i,j} = \frac{1}{2} \ln \left[\frac{1 + \hat{r}_{i,j}}{1 - \hat{r}_{i,j}} \right].$$

Распределение случайной величины $w_{i,j}$ асимптотически нормальное со средним значением и дисперсией, равными

$$\mu_w = \frac{1}{2} \ln \left[\frac{1 + r_{i,j}}{1 - r_{i,j}} \right], \quad \sigma_w^2 = \frac{1}{N-3}.$$

Величина порога, при заданном уровне значимости α , равна

$$\Delta = z_{\alpha/2} / \sqrt{N-3}.$$

При $|w_{i,j}| \leq \Delta$ принимается гипотеза H_0 , в противном случае гипотеза H_0 отклоняется. Величина $z_{\alpha/2}$ при заданном α определяется соотношением

$$\alpha/2 = \frac{1}{\sqrt{2\pi}} \int_{z_{\alpha/2}}^{\infty} e^{-\frac{z^2}{2}} dz.$$

Это эквивалентно сравнению выборочного значения коэффициента корреляции $\hat{r}_{i,j}$ с порогом

$$r^* = \frac{e^{\frac{2z_{\alpha/2}}{\sqrt{N-3}}} - 1}{e^{\frac{2z_{\alpha/2}}{\sqrt{N-3}}} + 1}.$$

При $|\hat{r}_{i,j}| \leq r^*$ принимается гипотеза H_0 , в противном случае она отклоняется. В табл. 2 приведены пороговые значения r^* для различных размеров скользящего окна и уровней значимости.

Для исследования ТП на информативность было выбрано девять фрагментов изображений размером 208×208 пикселей, три из которых показаны на рис. 2, для спутникового снимка MODIS, синтезированного по спектральным каналам 1, 3 и 4 с помощью программы ENVI. Выбранные каналы используются для исследования контуров облаков и земных объектов и их свойств. Все фрагменты обрабатывались скользящим окном размером $n_x \times n_y$ пикселей. Для каждого фиксированного положения окна вычислялось N значений всех исследуемых ТП по формулам (1)–(12). Затем рассчитывалась степень относительной изменчивости ТП δ_i , $i = \overline{1, 12}$ (13) и оценки коэффициентов корреляции $\hat{r}_{i,j}$ (14) всех пар признаков. В табл. 3 приведен пример результатов расчета оценок $\hat{r}_{i,j}$ для фрагмента изображения, показанного на рис. 2б, и размера скользящего окна 16×16 . Такие таблицы были рассчитаны для всех фрагментов изображения и размеров скользящего окна, приведенных в табл. 2. Для всех фрагментов изображения по таблицам оценивалась значимость коэффициентов корреляции описанным выше пороговым методом. Результаты исследований для трех фрагментов, показанных на рис. 2а, 2б, 2в, и размеров скользящего окна $n_x \times n_y = 16 \times 16$ приведены в табл. 4. Здесь для каждого ТП указа-

ны три значения $L_1/L_2/L_3$ числа L , каждое из которых определяет, сколько раз для оценок коэффициентов корреляции $\hat{r}_{i,j}$ i -го признака ($i \neq j$) на заданном фрагменте изображения выполнялось условие $|\hat{r}_{ij}| \leq r^*$. При этом L_1 соответствует фрагменту, показанному на рис. 2а, L_2 – на рис. 2б и L_3 – на рис. 2в. Из таблицы следует, что энтропия, инверсия (момент обратной разности), первый начальный момент и вариация становились независимыми (корреляция была менее 0.18) большее число раз (для энтропии $L_2 = 6$, для инверсии $L_2 = 5$, для первого начального момента $L_2 = 7$, для вариации $L_2 = 3$). А если учесть, что эти признаки имеют более высокую относительную изменчивость по сравнению с другими признаками, то это позволяет сделать вывод об их информативности для фрагмента, показанного на рис. 2б.

В табл. 5 обобщены результаты исследований на информативность всех выбранных фрагментов изображения. Приняты следующие обозначения: J – число фрагментов изображения, для которых степень изменчивости δ_i текстурного признака T_i превышала пороговое значение $\delta^* = 0.7$.

$$L_{\Sigma} = \sum_{i=1}^n L_i,$$

где i – номер фрагмента изображения, n – число выбранных фрагментов (в нашем случае $n = 9$). Величина $\delta_i = 0.7$ была выбрана опытным путем по результатам исследования различных фрагментов изображения. По этой таблице принималось решение об информативности того или иного ТП с учетом значений L_{Σ} и J . В нашем случае в качестве информативных признаков для сегментации можно рекомендовать дисперсию (9), энтропию (2), инверсию (момент обратной разности) (10), первый начальный момент (4) и вариацию (5), так как они имеют наибольшие значения L_{Σ} и J . Следует отметить, что наборы эффективных ТП для синтезированного изображения и монохромных изображений, построенных по данным отдельных каналов, не совпадают между собой. При этом каждое монохромное изображение имеет свой набор ТП. Для сравнения в табл. 5 приведены значения параметров $L_{\Sigma}(4)$, $J(4)$ для монохромного изображения, построенного по данным канала 4. В этом случае набор эффективных признаков включает в себя однородность (6), контраст (8), дисперсию (9), первый начальный момент (4) и отличается от соответствующего набора для синтезированного изображения. Стоит особо подчеркнуть, что для изображения, синтезированного по другим каналам, необходимо формировать свой набор эффективных ТП.

Исследования проводились для скользящих окон различного размера. Полученные результа-

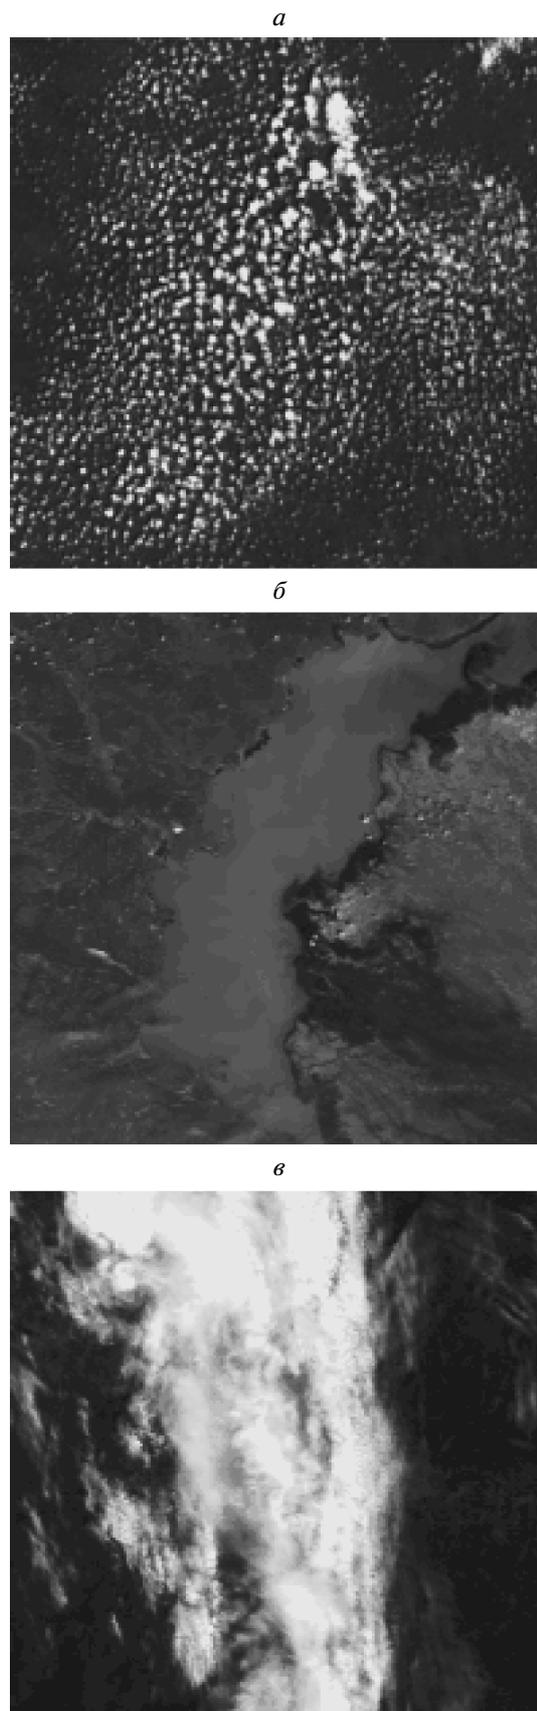


Рис. 2. а, б, в – исследуемые фрагменты спутникового снимка MODIS.

Таблица 3. Оценки значений коэффициентов корреляции $\hat{r}_{i,j}$ для $n_x \times n_y = 16 \times 16$ и фрагмента изображения, показанного на рис. 2б

Признаки	Однородность	Энергия	Контраст	Дисперсия	Энтропия	Максимальная вероятность	Инверсия	Первый начальный момент	Вариация	Второй угловой момент	Суммарное среднее	Суммарная энтропия
Однородность	1.000	0.782	0.974	0.216	0.172	0.659	0.372	-0.227	0.210	0.782	0.618	0.592
Энергия	0.782	1.000	0.868	-0.211	-0.179	0.937	0.285	-0.136	-0.218	1.000	0.376	0.007
Контраст	0.974	0.868	1.000	0.055	0.078	0.739	0.481	-0.227	0.048	0.868	0.579	0.440
Дисперсия	0.216	-0.211	0.055	1.000	0.786	-0.251	-0.096	-0.123	0.998	-0.211	0.237	0.758
Энтропия	0.172	-0.179	0.078	0.786	1.000	-0.248	0.162	-0.125	0.776	-0.179	0.273	0.684
Максимальная вероятность	0.659	0.937	0.739	-0.251	-0.248	1.000	0.112	-0.046	-0.258	0.937	0.299	-0.107
Инверсия	0.372	0.285	0.481	-0.096	0.162	0.112	1.000	-0.185	-0.101	0.285	0.315	0.223
Первый начальный момент	-0.227	-0.136	-0.227	-0.123	-0.125	-0.046	-0.185	1.000	-0.120	-0.136	0.525	-0.248
Вариация	0.210	-0.218	0.048	0.998	0.776	-0.258	-0.101	-0.120	1.000	-0.218	0.236	0.757
Второй угловой момент	0.782	1.000	0.868	-0.221	-0.179	0.937	0.285	-0.136	-0.218	1.000	0.376	0.007
Суммарное среднее	0.618	0.376	0.579	0.237	0.273	0.299	0.315	0.525	0.236	0.376	1.000	0.496
Суммарная энтропия	0.592	0.007	0.440	0.758	0.684	-0.107	0.223	-0.248	0.757	0.007	0.496	1.000
Степень изменчивости	0.177	0.676	0.394	0.968	0.573	0.486	0.249	0.989	0.089	0.676	0.960	0.791

Таблица 4. Результаты оценки значимости коэффициентов корреляции для фрагментов изображения, показанных на рис. 2

Текстурные признаки	$L_1/L_2/L_3$	
	$\alpha = 0.01, r^* = 0.18$	$\alpha = 0.1, r^* = 0.12$
Однородность	2/1/2	2/0/1
Энергия	0/3/1	0/1/0
Контраст	0/3/5	0/3/4
Дисперсия	0/3/3	0/3/2
Энтропия	2/6/1	2/2/1
Максимальная вероятность	0/3/1	0/3/0
Инверсия	0/5/6	0/3/4
Первый начальный момент	2/7/4	2/4/3
Вариация	0/4/2	0/3/2
Второй угловой момент	0/3/1	0/1/0
Суммарное среднее	2/0/2	2/0/1
Суммарная энтропия	0/3/0	0/3/0

ты обобщены в табл. 6, в которой выделены четыре наиболее информативных ТП для каждого размера окна. Из указанной таблицы видно, что наиболее информативные признаки совпадают для

скользящих окон размером 20×20 и 40×40 пикселей. Это свидетельствует о нецелесообразности дальнейшего увеличения размера скользящего окна. Аналогичный результат отмечен в работе

Таблица 5. Результаты исследований на информативность ТП выбранных фрагментов изображения для уровня значимости $\alpha = 0.01$

Текстурный признак	$L_{\Sigma}(4)$	$J(4)$	L_{Σ}	J
Однородность	26	7	19	0
Энергия	14	4	17	5
Контраст	25	6	20	0
Дисперсия	22	9	19	9
Энтропия	21	7	24	5
Максимальная вероятность	21	0	22	0
Инверсия	22	5	22	3
Первый начальный момент	35	6	34	9
Вариация	19	9	20	9
Второй угловой момент	14	5	17	4
Суммарное среднее	8	1	5	2
Суммарная энтропия	20	0	15	0

Таблица 6. Наборы информативных текстурных признаков для уровня значимости $\alpha = 0.01$

$n_x \times n_y = 4 \times 4$	8×8	16×16	20×20	40×40
Однородность <i>Энтропия</i>	Дисперсия <i>Инверсия</i>	<i>Энтропия</i> Максимальная вероятность	<i>Энтропия</i> Максимальная вероятность	<i>Энтропия</i> Максимальная вероятность
Первый начальный момент	Первый начальный момент	Инверсия	Первый начальный момент	Первый начальный момент
Суммарное среднее	Суммарное среднее	Первый начальный момент	Суммарная энтропия	Суммарная энтропия

(Потапов, 2003), где показано, что при изменении размеров окна от 20×20 до 80×80 пикселей численные значения текстурных признаков изменялись всего на 5–10%. Там же говорится, что окна 20×20 пикселей наиболее эффективны для текстурной обработки аэрокосмических фотографий с.-х. угодий, пастбищ, лесных массивов и других сходных объектов. А в окнах размером 3×3 или 5×5 пикселей статистические текстурные меры больше действуют как обнаружители перепадов яркости, а не как измерители текстуры.

АЛГОРИТМ СЕГМЕНТАЦИИ НА ОСНОВЕ ТЕХНОЛОГИИ НЕЙРОННЫХ СЕТЕЙ

Для сегментации спутниковых изображений нами выбрана однослойная нейронная сеть Кохонена с алгоритмом обучения СВТА (победитель получает все с механизмом утомления) как наиболее эффективным, обеспечивающим минимум ошибок квантования (Осовский, 2002; Хайкин, 2008). К числу основных преимуществ нейронных сетей относятся возможность использовать их для обработки искаженных и зашумленных данных, а также возможность организации параллельных вы-

числений (Осовский, 2002; Хайкин, 2008), что может обеспечить высокую производительность при обработке больших массивов данных ДЗЗ из космоса. На рис. 3 показана архитектура выбранной однослойной сети. На ее вход подаются признаки, используемые для сегментации спутникового изображения. Входной нормированный вектор признаков $x = X/\|X\|$, где $X = (X_1, X_2, X_3, X_4, \dots, X_{s+3})^T$, $X_1 = X_R, X_2 = X_G, X_3 = X_B, X_4 = X_{i1}, \dots, X_{s+3} = X_{is}$ – средние значения цветовых компонентов выделенной части фрагмента изображения скользящим окном; $X_4 = T_{i1}, \dots, X_{s+3} = T_{is}$ – набор текстурных признаков, число которых равно s . Число нейронов равно p . Отклик u_j нейрона j определяется выражением

$$u_j = \sum_{i=1}^{s+3} w_{ji}x_i,$$

где

$$W_j = (w_{j1}, w_{j2}, \dots, w_{j(s+3)})^T$$

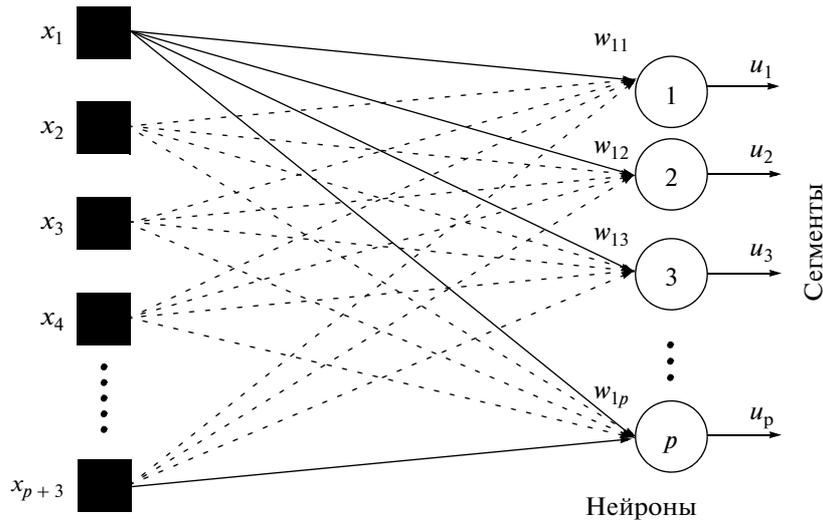


Рис. 3. Архитектура самоорганизующейся нейронной сети Кохонена.

– вектор синаптических весов нейрона j . По результатам сравнения откликов всех нейронов победителем признается тот нейрон, значение $u_j / N_j(l)$ у которого будет наибольшим. Здесь $N_j(l)$ – число побед нейрона j на шаге l . Нейрон-победитель вырабатывает на своем выходе состояние 1, а остальные (проигравшие) нейроны переходят в состояние 0. Такой подход реализует ступенчатую функцию активации нейронов. В процессе обучения для активированного нейрона-победителя происходит уточнение вектора весовых коэффициентов \mathbf{W}_j на шаге l по правилу Гроссберга

$$\mathbf{W}_j(l+1) = \mathbf{W}_j(l) + \eta(l)(\mathbf{x} - \mathbf{W}_j(l)), \quad (15)$$

где $\eta(l)$ – параметр скорости обучения сети, который определяет точность и производительность процесса самоорганизации (Хайкин, 2008). Нейроны уточняют свои весовые коэффициенты таким образом, что при предъявлении группы близких по значениям входных векторов победителем всегда оказывается один и тот же нейрон. В процессе обучения сети именно этот нейрон определяет свою категорию данных в пространстве решений. Такая процедура называется самоорганизацией процесса обучения. Чем больше число нейронов, тем более детально будет выполняться сегментация изображения. Однако при этом могут появиться сегменты, содержащие всего один пиксел, а некоторые нейроны могут и вовсе не активироваться.

В процессе обучения нейронной сети и при сегментации изображения скользящее окно движется вправо, начиная с левого верхнего угла изображения, смещаясь каждый раз на один пиксел. После достижения правого края изображения осуществляется возврат окна к левой границе

изображения со сдвигом вниз на один пиксел вниз и т.д. В процессе обучения на первом этапе сканируется все изображение, а при повторном сканировании обучение прекращается при выполнении для всех нейронов условий

$$\sqrt{\sum_{i=1}^{s+3} (w_{ji}(n+1) - w_{ji}(n))^2} \leq 1, \quad j = \overline{1, p}.$$

С учетом особенностей этапа обучения сети, было выбрано постоянное значение параметра $\eta(l)$ в выражении (15), равное 0.05. Процесс сегментации настроенной нейронной сетью подобен процедуре обучения. Разница заключается в том, что после определения нейрона-победителя происходит не уточнение его весовых коэффициентов, а перекрашивание центрального пиксела скользящего окна в цвет сегмента, который представляет нейрон-победитель.

Для оценки результативности проведенных исследований была выполнена сегментация спутникового изображения по RGB-компонентам цвета, с использованием неинформативных ТП и с помощью найденного набора информативных ТП. На рис. 4 представлены исходный фрагмент изображения (рис. 4а) и результаты его сегментации: по RGB-компонентам (рис. 4б), когда $\mathbf{X} = (X_R, X_G, X_B)^T$; с использованием RGB-компонентов и трех ТП – вариация, контраст и суммарное среднее (рис. 4в), что соответствует $\mathbf{X} = (X_R, X_G, X_B, T_5, T_8, T_{11})^T$; с использованием RGB-компонентов и набора информативных ТП – энтропия, максимальная вероятность, первый начальный момент и инверсия (рис. 4г), когда $\mathbf{X} = (X_R, X_G, X_B, T_2, T_3, T_4, T_{10})^T$.

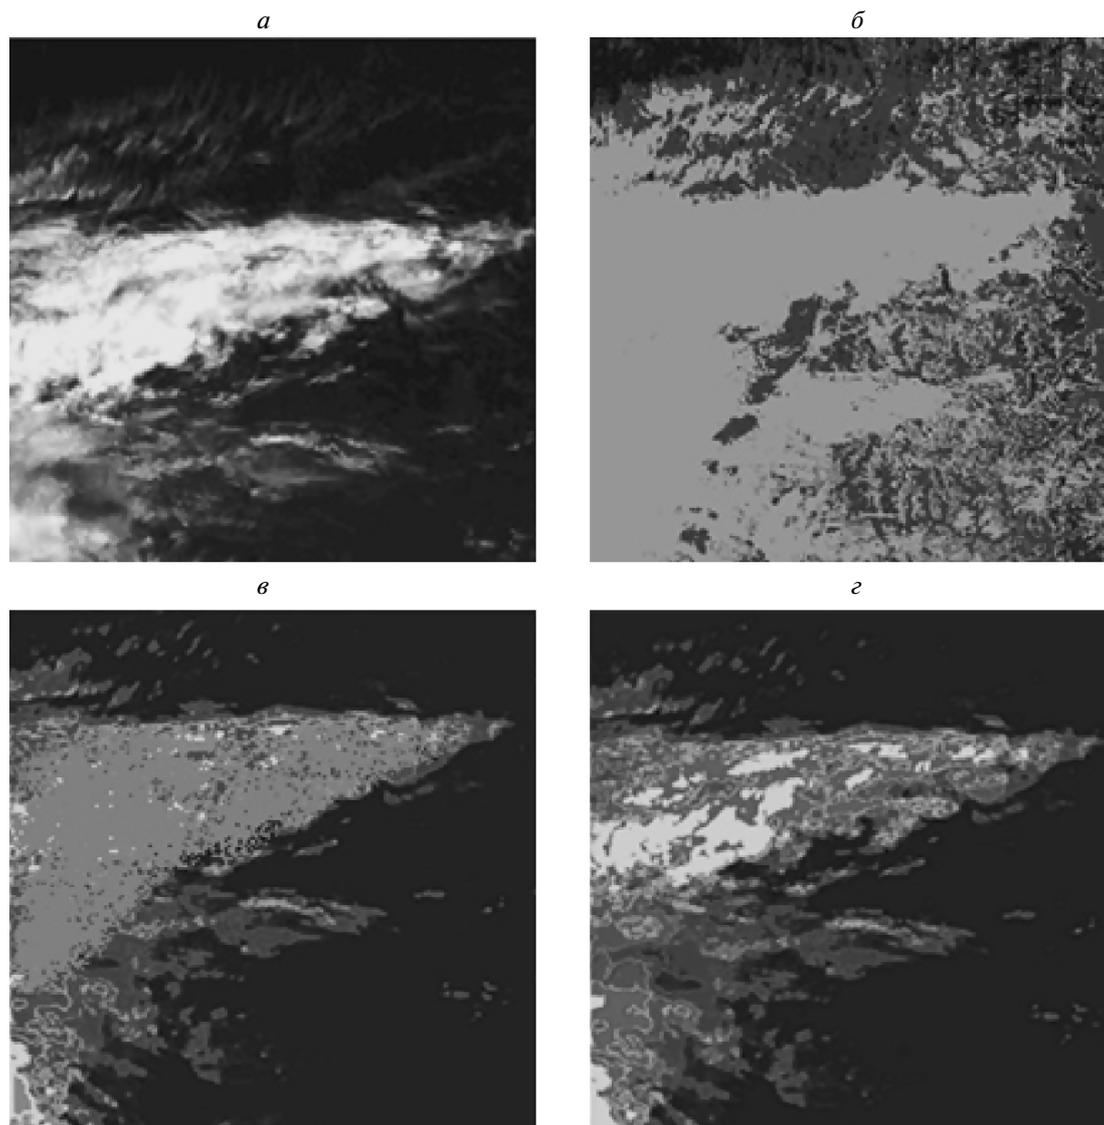


Рис. 4. Исходные фрагмент изображения (а) и результаты его сегментации (б, в, з).

На рис. 4б различные структуры изображения облачного поля слились в один сегмент (недостаточная сегментация), поскольку текстура изображения при сегментации не учитывалась. Использование нескольких ТП дает более подробное разделение на сегменты (рис. 4в), потому что даже неинформативные признаки позволяют различать текстуры изображения. Однако полученный результат также можно отнести к недостаточной сегментации, потому что визуально не видны границы между сегментами неоднородных областей облачного поля. Как видно из рис. 4з, использование набора информативных ТП позволило выполнить более детальную сегментацию облачного поля по его текстуре, а сегменты облачного поля имеют четкие границы и визуально различимы между собой.

ЗАКЛЮЧЕНИЕ

Результаты исследований подтверждают эффективность предложенного подхода к формированию наборов информативных ТП для спутниковых изображений, который основан на анализе степени изменчивости текстурных признаков и величине коэффициентов их корреляции. С помощью этой методики для различных размеров скользящего окна сформированы наборы информативных ТП для спутникового изображения, полученного по спектральным каналам видимого диапазона спектра радиометра MODIS. Для окна размером 20×20 набор информативных признаков включает в себя энтропию, максимальную вероятность, первый начальный момент и суммарную энтропию. Показано, что дальнейшее увели-

чение размера скользящего окна не приводит к изменению указанного набора признаков.

Проведение подобных исследований для изображений различных типов облаков и подстилающей поверхности с учетом разрешающей аппаратуры ДЗЗ позволит в перспективе составить для них наборы информативных ТП и их значений. Их применение в качестве исходной информации в алгоритмах на основе нейронных сетей позволит ставить и решать задачу классификации различных типов облаков и участков подстилающей поверхности на спутниковых изображениях.

Работа выполнена при частичной финансовой поддержке Минобрнауки РФ (госконтракт № 02.740.11.0674).

СПИСОК ЛИТЕРАТУРЫ

- Бендат Дж., Пирсол А.* Прикладной анализ случайных данных / Пер. с англ. М.: Мир, 1989. 540 с.
- Герман М.А.* Спутниковая метеорология. Л.: Гидрометеоздат, 1975. 368 с.
- Захваткина Н.Ю., Александров В.Ю., Коросов А.А., Йоханнессен О.М.* Классификация морских льдов на РСА изображениях спутника ENVISAT // Современные проблемы дистанционного зондирования Земли из космоса / Под ред. Лаверова Н.П., Лупяна Н.А., Лавровой О.Ю. 2009. Т. 1. С. 373–379.
- Облака и облачная атмосфера.* Справочник / Под ред. Мазина И.П., Хргиана А.Х. Л.: Гидрометеоздат, 1989. 647 с.
- Мицель А.А., Колодникова Н.В., Протасов К.Т.* Непараметрический алгоритм текстурного анализа // Изв. Томского политехнического университета. 2005. Т. 308. № 1. С. 65–70.
- Осовский С.* Нейронные сети для обработки информации / Пер. с польск. Рудинского И.Д. М.: Финансы и статистика, 2002. 344 с.
- Потапов А.А.* Новые информационные технологии на основе вероятностных текстурных и фрактальных признаков в радиолокационном обнаружении мало-контрастных целей // Радиотехника и электроника. 2003. Т. 48. № 9. С. 1101–1119.
- Хайкин С.* Нейронные сети: Полный курс / Пер. с англ. Кузсуль Н.Н., Шелестовой А.Ю. М.: Издательский дом Вильямс, 2008. 1103 с.
- Харалик Р.М.* Статистический и структурный подходы к описанию текстур // ТИИЭР. 1979. Т. 67. № 5. С. 98–120.
- Shiffman S.* Cloud detection from satellite imagery: a comparison of expert-generated and automatically-generated decision trees. 2004. http://ntrs.nasa.gov/archive/nasa/casi.ntrs.nasa.gov/20050157894_2005141745.pdf

Segmentation of Satellite Images by Textural Parameters Based on Neural Network Technologies

V. G. Astafurov^{1,2}, A. V. Skorokhodov²

¹ Tomsk State University of Control Systems and Radioelectronics, Tomsk

² V.E. Zuev Institute of Atmospheric Optics of the Siberian Branch of the Russian Academy of Sciences, Tomsk

A new approach to the formation of sets of informative textural parameters determined on the basis of the adjacency matrix of image brightness gradations is suggested. The method is based on an analysis of the degree of variability of the textural parameters and values of their correlation coefficients. Sets of the informative parameters for satellite images of the MODIS spectral radiometer and several sizes of the sliding window are given. An algorithm based on the self-organizing Kohonen neural network is used for segmentation of satellite images. Results of segmentation are discussed.

Keywords: cloud types, segmentation, textural parameters, neural network